Journal of Agricultural Machinery
Vol. 11, No. 2, Fall- Winter 2021, p. 447-464

نشریه ماشین‌های کشاورزی
جلد ۱۱، شماره ۲، نیمسال دوم ۱۴۰۰، ص ۴۶۴-۴۴۷

مقاله علمی-پژوهشی

ارزیابی چند شاخص طیفی برای برآورد عملکرد کلزا با استفاده از تصاویر سنجنده سنتینل-۲

نعیم لویمی[۱]، اسداله اکرم[۲*]، نیکروز باقری[۳]، علی حاجی احمد[۴]

تاریخ دریافت: ۱۳۹۸/۰۲/۰۳
تاریخ پذیرش: ۱۳۹۸/۰۴/۲۳

چکیده

سنجش از دور و به‌کارگیری تصاویر ماهواره‌ها به‌علت سرعت کار و گستردگی سطح پوشش بسیار مورد توجه قرار گرفته است. کلزا به‌دلیل گل‌های زرد آن دارای رنگ پوشش گیاهی متفاوتی با سایر محصولات است و تحقیقات کمی در زمینه ارزیابی شاخص‌های طیفی به‌منظور پیش‌بینی عملکرد آن انجام گردیده است. در سال زراعی ۹۶-۹۵ با هدف پیش‌بینی عملکرد کلزا ده شاخص طیفی سنجنده سنتینل-۲، مورد ارزیابی قرار گرفت. این تحقیق به شکل پیکسل‌مبنا در سه مزرعه انجام شد و محدوده شبکه‌ای پیکسل‌های مزارع با کمک سیستم موقعیت‌یابی جهانی سینماتیک زمان واقعی (RTKGPS) تعیین گردید. در این تحقیق مدل‌های رگرسیونی خطی ساده و چند متغیره و نیز شبکه عصبی به‌کار رفت. نتایج نشان داد براساس مدل رگرسیون خطی ساده، بین مراحل مختلف رشد، بیشترین ضریب تبیین (R^2) در هر یک از شاخص‌های گیاهی در یکی از دو مرحله اوج گل‌دهی و رسیدگی سبز رخ می‌دهد. براساس این مدل، در مرحله اوج گل‌دهی، شاخص تفاضل نرمال شده زردی (NDYI) با ۷۳ درصد بیشترین ضریب تبیین را نسبت به سایر شاخص‌ها احراز کرد. با به‌کارگیری مدل رگرسیون خطی چند متغیره گام به گام با ورودی چهار باند، سه باند مرئی و باند مادون قرمز نزدیک، بهترین مدل در مرحله اوج گل‌دهی با ضریب تبیین ۷۶ درصد و اعتبارسنجی ۷۳ درصد با ریشه میانگین مربعات خطا (RMSE) به‌میزان ۰/۶۴۱ به‌دست آمد. همچنین با استفاده از مدل شبکه عصبی و ورود چهار باند مذکور نیز بهترین مدل در مرحله اوج گل‌دهی با ضریب تبیین ۹۲ درصد (آموزش) و اعتبارسنجی (آزمون) ۷۷ درصد با RMSE به‌میزان ۰/۶۱۲ احراز شد.

واژه‌های کلیدی: پیش‌بینی عملکرد، سنجش از دور، سنجنده سنتینل-۲، شاخص گیاهی، شاخص NDYI

مقدمه

مصرف سرانه روغن خوراکی کشور حدود ۱۶ کیلوگرم برآورده شده و نیاز داخلی حدود یک میلیون تن می‌باشد که بیش از ۹۱ درصد آن از خارج وارد می‌شود (Roodi *et al.*, 2004). در حال حاضر تعداد محدودی دانه‌های روغنی در کشور ما مورد توجه قرار می‌گیرد که از جمله آن‌ها و براساس بیشترین سطح زیر کشت می‌توان به سویا، آفتابگردان، کلزا و گلرنگ اشاره نمود (Kazem *et al.*, 2016). توسعه کشت سویا، آفتابگردان، کنجد و گلرنگ در کشور ما با مشکلاتی روبه‌رو است (Roodi *et al.*, 2004). از این‌رو وزارت جهاد کشاورزی برای تأمین نیاز داخلی روغن خوراکی کشور برنامه حمایتی برای افزایش توسعه کشت کلزا در کشور را تدوین نموده است که باعث افزایش سطح زیر کشت این محصول در سال‌های اخیر شده است (Norgholipor *et al.*, 2014; Roodi *et al.*, 2004).

طی چهار دهه اخیر، کشت جهانی کلزا به سرعت رشد کرده و از رتبه شش محصولات روغن گیاهی به رتبه دوم، بعد از سویا، ارتقاء یافته است؛ از لحاظ روغن گیاهی نیز کلزا بعد از سویا و نخل پالم سوم می‌باشد (Ash, 2017). دانه کلزا دارای میزان روغن بالا و نیز کنجاله آن غنی از پروتئین می‌باشد به‌طوری که دانه کلزا ۴۵-۳۸ درصد روغن، و کنجاله آن ۳۸-۳۴ درصد پروتئین دارد (Ash, 2017).

کسب اطلاعات و جمع‌آوری آمار و ارقام از ویژگی‌های منابع زمینی، هر روز بیشتر از روز پیش ضرورت می‌یابد. به‌نظر می‌رسد دست‌یابی به یک بانک اطلاعات در این زمینه، بدون صرف هزینه زیاد، تنها با بهره‌گیری از علم سنجش از دور امکان‌پذیر باشد (Alizadeh Rabie, 2014). جمع‌آوری اطلاعات تولید محصولات که در سطح ملی و منطقه‌ای به‌وسیله پیمایش و سرشماری در کشورها معمول است بسیار هزینه‌بر و غیردقیق است (Gallego *et al.*, 2010). در مقابل، اندازه‌گیری‌های مخرب شاخص‌های محصول همچون عملکرد علاوه بر نیاز به زمان، به‌کارگیری آن‌ها در سطح وسیع عملی نمی‌باشد (Boschetti *et al.*, 2007). پژوهش در حوزه‌های سنجش از دور به دلیل هزینه مناسب، سرعت بالا و دقت

۱- دانشجوی دکتری گروه مهندسی ماشین‌های کشاورزی، دانشکده مهندسی و فن‌آوری کشاورزی، پردیس کشاورزی و منابع طبیعی، دانشگاه تهران، کرج، ایران
۲- دانشیار، گروه مهندسی ماشین‌های کشاورزی، دانشکده مهندسی و فناوری کشاورزی، پردیس کشاورزی و منابع طبیعی، دانشگاه تهران، کرج، ایران
۳- استادیار پژوهش، موسسه تحقیقات فنی و مهندسی کشاورزی، سازمان تحقیقات، آموزش و ترویج کشاورزی، کرج، ایران
۴- استادیار، گروه مهندسی ماشین‌های کشاورزی، دانشکده مهندسی و فناوری کشاورزی، پردیس کشاورزی و منابع طبیعی، دانشگاه تهران، کرج، ایران
(*- نویسنده مسئول: Email: aakram@ut.ac.ir)
DOI: 10.22067/jam.v11i2.80232

قابل قبول برای تصمیم‌سازی و مدیریت منابع، دارای اهمیت زیادی است (Mcbratney *et al.*, 2005).

برآورد میزان محصول علاوه بر کمک به مدیریت زمین‌های کشاورزی و کاهش هزینه‌های داشت و برداشت محصول، می‌تواند به ارزیابی میزان کود و مواد شیمیایی مورد نیاز مزرعه نیز کمک نماید، ضمن این که در پیش‌بینی فضای مورد نیاز برای ذخیره محصول برداشتی نیز مفید خواهد بود (Yamamoto *et al.*, 2014).

شاخص‌های طیفی گیاهی[1] شامل روابط مختلف ریاضی هستند که برای تحلیل اطلاعات تصاویر ماهواره‌ای برای تعیین صفات و ویژگی‌های گیاه همچون تراکم (Johnson *et al.* 2003)، میزان زیست‌توده[2] (Ahamed *et al.*, 2011)، نیاز کودی (Li *et al.*, 2008) و یا موارد مدیریتی همچون تفکیک محصولات (Sicre *et al.*, 2016) و مدیریت بقایا (Rostami and Afzali Grouh, 2017) مورد استفاده قرار می‌گیرند. مطالعات زیادی به ارتباط بین داده‌های طیفی ناشی از محصول و صفات متعدد بیولوژیکی و فیزیولوژیکی دست یافته‌اند (Goel *et al.*, 2003; Jago *et al.*, 1999; Lee *et al.*, 2004; Vigneau *et al.*, 2011; Zou *et al.*, 2011). امروزه یکی از مهم‌ترین موضوعات سنجش از دور، ارزیابی شاخص‌های طیفی بر حسب میزان حساسیت آن‌ها به ویژگی‌های بیوفیزیکی گیاهان و نیز عوامل موثر در بازتاب‌های طیفی پوشش محصول است (Alavipanah, 2016). شاخص تفاضل پوشش گیاهی نرمال شده (NDVI[3]) مدت‌ها است که به‌عنوان یک روش غیرمستقیم برای تعیین عملکرد محصول استفاده می‌شود (Raun *et al.*, 2001). در دهه‌های اخیر به منظور بهبود شاخص NDVI و ارائه شاخص‌های جدید برای اصلاح اثرات خاک و اتمسفر، تلاش‌های زیادی صورت گرفته است (Alavipanah, 2016). گزارش شده که شاخص نسبت پوشش گیاهی (RVI[4]) در تخمین عملکرد گندم دوروم مناسب‌تر از شاخص NDVI است (Aparicio *et al.*, 2000). وضعیت مشابهی نیز برای برآورد عملکرد ذرت به‌دست آمد (Shanahan *et al.*, 2001). ارزیابی انجام شده برای پیش‌بینی عملکرد دانه ذرت که در رژیم های آبیاری متفاوتی قرار داشت، نشان داد که بین شاخص‌های طیفی منتج از برگشت نوری پوشش گیاهی[5] و عملکرد محصول ارتباط قوی وجود دارد (Weber *et al.*, 2012).

در کشور ما در زمینه بررسی محصول کلزا از طریق طیف‌های ماهواره‌ای، تحقیقات محدودی صورت گرفته است. پژوهش انجام شده در دشت ناز ساری جهت تفکیک محصول کلزا از سایر پدیده‌ها و محاسبه سطح زیر کشت آن با استفاده از ماهواره لندست-۸، نشان داد که بهترین زمان برای تخمین سطح زیر کشت این محصول در مرحله گل‌دهی آن است (Khalili *et al.*, 2016). نتایج ارزیابی شاخص NDVI، شاخص تفاضل پوشش گیاهی نرمال شده سبزینگی (GNDVI[6])، شاخص گیاهی تعدیل‌شده با خاک (SAVI[7]) و شاخص پوشش گیاهی تعدیل شده (EVI[8]) منتج از ماهواره لندست-۸ برای تخمین عملکرد کلزا در جنوب غربی خوزستان نشان داد که بیشترین ضریب تبیین (R^2)، به‌ترتیب متعلق به GNVI و NDVI با ۵۵ و ۵۱ درصد می‌باشد (Zahirnia *et al.*, 2016). بررسی هفت شاخص طیفی حاصل از ماهواره لندست-۸ برای برآورد عملکرد کلزا در منطقه کرج نشان داد شاخص‌های NDYI[9] با ۶۷ درصد و RVI با ۶۴ درصد بیشترین ضریب تبیین را کسب نمودند (Loveimi *et al.*, 2019).

نتایج ارزیابی محصولات جو، کلزا، نخود و گندم بهاره به‌وسیله سنجنده مودیس نشان داد که بین مناطق خشک، نیمه‌خشک و مرطوب، بیشترین همبستگی عملکرد این محصولات با شاخص NDVI مربوط به منطقه نیمه‌خشک می‌باشد. همچنین ضریب تبیین، با توجه به مناطق متفاوت مورد مطالعه، برای این محصولات به‌ترتیب ۹۰-۴۸، ۸۲-۳۲، ۸۹-۵۳ و ۸۰-۴۷ درصد گزارش شده است (Mkhabela *et al.*, 2011). مطالعه ۴ ساله روی ۱۵۰ ذخایر توارثی[10] کلزا برای بررسی امکان به‌کارگیری حسگر سبزینه‌سنج[11] دستی به‌منظور تشخیص ذخایر توارثی با عملکرد بالا، براساس پوشش گیاهی محصول در طول دوره رشد، نشان داد که بیشترین میزان همبستگی بین عملکرد و شاخص NDVI در میانه رشد، ۳۲۰-۲۱۰ روز رشد، با ضریب همبستگی در محدوده ۰/۷ می‌باشد (Cowley *et al.*, 2014).

تحقیقات صورت گرفته با استفاده از شبکه عصبی مصنوعی[12] و تصاویر ماهواره‌ای جهت پیش‌بینی عملکرد سویا در ۱۱ ایالت آمریکا نشان داد که میزان همبستگی حاصل از شبکه عصبی با اختلاف کمی بهتر از رگرسیون چند متغیره است (Li *et al.*, 2007). در تحقیق مذکور بیشترین مقادیر ضریب تبیین ثبت شده در بین ایالت‌های مورد ارزیابی، به‌ترتیب برای شبکه عصبی و رگرسیون چند متغیره، ۹۴ و ۸۶ درصد و کمترین آنها به‌ترتیب ۵۳ و ۳۳ درصد گزارش شده است. نتایج تحقیق دیگر در سه سال مختلف در مورد تخمین عملکرد ذرت با استفاده از شبکه عصبی و به‌کارگیری ۱۰۰ داده در هر سال نشان داد که بین شاخص‌های GNDVI، NDVI، SAVI و شاخص

1- Spectral Vegetation Indices
2- Biomass
3- Normalized Difference Vegetation Index
4- Ratio Vegetation Index
5- Canopy
6- Green Normalization Difference Vegetation Index
7- Soil Adjusted Vegetation Index
8- Enhanced Vegetation Index
9- Normalized Difference Yellowness Index
10- Germplasm
11- GreenSeeker
12- Artificial Neural Net (ANN)

گیاهی خط عمودی خاک (PVI[1])، شاخص اخیر یعنی PVI با توانایی بیشتری توانست عملکرد را پیش‌بینی نماید (Panda *et al.*, 2010). مقادیر ضریب تبیین برای سه شاخص GNDVI، NDVI و SAVI، به‌ترتیب بین ۹۴-۲۴، ۹۵-۱۹/۳ و ۹۵-۱۹/۲درصد به‌دست آمد، در حالی‌که این مقادیر برای شاخص PVI بین ۸۳ تا ۹۶ درصد بود.

به‌دلیل عمر کوتاه سنجنده سنتینل-۲، مطالعات محدودی در زمینه پایش محصولات کشاورزی از جمله عملکرد محصولات توسط آن صورت گرفته شده است. ارزیابی مزارع ذرت به‌وسیله این سنجنده نشان داد که براساس رگرسیون چند متغیره و سه ورودی شامل شاخص NDVI، شاخص تفاضل پوشش گیاهی نرمال شده سبز (NDVIG[2]) و شاخص تفاضل پوشش گیاهی نرمال شده لبه قرمز (NDVIre[3])، ضریب تبیین در دو استان مختلف مورد مطالعه ۰/۶۸ و ۰/۵۹ و به‌طور کل ۰/۳۲ بوده است (Schwalbert *et al.*, 2018).

مقایسه تصاویر از مرحله اول جوانه‌زنی تا مرحله غلاف‌دهی و رسیدگی کامل محصول به‌وسیله طیف‌سنجی زمینی نشان داد بهترین زمان تصویربرداری برای برآورد عملکرد، اوج گل‌دهی کلزا است (Sulik and Long, 2016; Zhang and He, 2013). در مطالعه روی کلزا (Sulik and Long, 2016) و براساس طیف‌سنجی زمینی (نصب طیف‌سنج بر سکوی متحرک) برای اولین بار برای برآورد عملکرد آن شاخص جدید NDYI تعریف شد. این شاخص در سطح مزارع و به‌وسیله تصاویر سنجنده مودیس نیز ارزیابی گردید. در تمام ارزیابی‌های صورت گرفته، در سطح پلات‌ها با کمک طیف‌سنج و نیز در سطح مزارع با به‌کارگیری تصاویر مودیس، این شاخص نتایج بهتری کسب کرد. در یک مقایسه در این تحقیق ضریب تبیین بین عملکرد و شاخص جدید NDYI مقدار ۷۲ درصد به‌دست آمد در حالی که این ضریب برای NDVI به میزان ۶۶ درصد بود. اهمیت این شاخص جدید به این دلیل است که تمام مطالعات قبل صورت گرفته برای سنجش محصول کلزا توسط سنجنده‌های ماهواره‌ها، مقادیر رابطه پایینی بین عملکرد و شاخص‌های طیفی گیاهی معمول همچون NDVI را گزارش داده بودند. این مسأله ناشی از تفاوت ظاهر محصول کلزا با محصولات دیگر می‌باشد که پوشش گیاهی کلزا از میانه رشد به بعد به رنگ زرد تغییر می‌کند در حالی که پوشش گیاهی محصولات دیگر همیشه سبز می‌باشد. به همین دلیل مطالعات قبلی علت ارتباط کم عملکرد و شاخص NDVI را ناشی از رنگ پوشش گیاهی زرد گل‌های کلزا عنوان کردند (Basnyat *et al.*, 2004). بررسی ارتباط شاخص‌های طیفی گیاهی حاصل از سنجنده ETM+ ماهواره لندست و عملکرد کلزا در مراحل مختلف رشد نشان داد که همه شاخص‌های مورد ارزیابی رابطه نسبتاً ضعیفی با عملکرد دارند (Dominguez *et al.*, 2017). در این مطالعه شاخص‌های NDVI و GNVI نتایج بهتری در مقایسه با شاخص‌های دیگر کسب کردند و سایر شاخص‌های مطالعه حاضر بررسی نشدند. مطالعه دیگر نشان داد که ارتباط عملکرد کلزا و شاخص NDVI به موازات افزایش میزان گل‌دهی در طول رشد، کاهش می‌یابد (Piekarczyk, 2011). در واقع تخمین عملکرد کلزا در مراحل رشد به‌وسیله شاخص‌های طیفی همچون NDVI با رابطه ضعیف گزارش شده است (Pratt, 2013). همچنین مطالعه جامعی که در طول سال‌های ۲۰۰۸ تا ۲۰۱۳ در مزارع آمریکا بر محصولات متنوع زراعی انجام شد، نشان داد میزان همبستگی شاخص‌های گیاهی منتج از سنجنده مودیس، وضوح ۲۵۰ متری، با عملکرد کلزا نسبت به گندم، جو، ذرت، پنبه، سیب‌زمینی، سورگوم، سویا و چغندرقند بسیار پایین‌تر است (Johnson, 2016).

اکنون با توجه به مشکلات پیش‌بینی عملکرد کلزا و نیز جدید و در دسترس بودن تصاویر سنجنده سنتینل-۲ با قدرت تفکیک مکانی و زمانی مناسب، این پژوهش با هدف ارزیابی شاخص‌های مختلف طیفی جدید و متداول منتج از این سنجنده برای تخمین عملکرد کلزا بنا شده است. این تحقیق در مراحل مختلف رشد محصول انجام شده، لذا مقایسه توانایی هر یک از این شاخص‌ها در هر یک از این مراحل مورد بررسی قرار گرفته است. علاوه بر این، ارزیابی "معادل شاخص طیفی" با به‌کارگیری ترکیب باندها به‌وسیله رگرسیون چند متغیره و نیز بررسی توانایی شبکه عصبی مصنوعی برای پیش‌بینی عملکرد کلزا اهداف دیگر این مطالعه است.

مواد و روش‌ها

مکان و شرایط تحقیق

این پژوهش در سال زراعی ۹۶-۹۵ در شهرستان کرج، زمین آزمایشی موسسه تحقیقات اصلاح بذر، با عرض جغرافیایی ۳۵درجه و ۴۷دقیقه و ۴۸ثانیه شمالی و طول جغرافیایی ۵۰درجه و ۵۵دقیقه و ۵۸ثانیه شرقی انجام گردید. در این سال زراعی، در زمین مذکور، کشت کلزا در سه مزرعه با مساحت حدود ۱/۸، ۲/۶ و ۲ هکتار انجام گرفت، که به‌عنوان محل این آزمایش انتخاب شدند (شکل ۱).

هر سه مزرعه از نظر زمان کاشت و رسیدگی‌های زراعی در طول رشد شرایط مشابه داشتند. عملیات کاشت در مهرماه صورت گرفت و آبیاری و نیز کوددهی و سم‌پاشی در طول رشد و با فاصله کوتاه و گاه در یک روز برای سه مزرعه انجام شد. لذا پنج مرحله رشد مورد ارزیابی شامل مرحله قبل از شروع گل‌دهی (قبل از ساقه رفتن)، ابتدای گل‌دهی (ابتدای ساقه رفتن)، اوج گل‌دهی، رسیدگی سبز (کامل شدن غلاف) و رسیدگی خشک در سه مزرعه با فاصله حداکثر دو تا چهار روز شروع و پایان یافتند و همگی از نیمه دوم اسفند تا اواخر خرداد رخ دادند. یادآور می‌گردد این مراحل مهم‌ترین دوره‌های

1- Perpendicular Vegetation Index (PVI)
2- Green NDVI
3- Red-edge NDVI

رشد می‌باشند که در این تحقیق برای ارزیابی روابط تصاویر سنجنده با عملکرد مورد ارزیابی قرار گرفتند.



شکل ۱– موقعیت سه مزرعه آزمایشی کلزا: F1: مزرعه اول، F2: مزرعه دوم F3: مزرعه سوم

Fig.1. The location of the three experimental canola farms: F1: Farm1, F2: Farm2, F3: Farm3

تصاویر سنجنده و پردازش آن‌ها

سنجنده سنتینل-۲ متشکل از دو ماهواره خورشیدآهنگ است. اولین ماهواره آن در ژوئن ۲۰۱۵ و دومین آن در مارس ۲۰۱۷ راه‌اندازی شد. این ماهواره از ۱۳ باند طیفی در محدوده‌های مرئی، مادون قرمز نزدیک و مادون قرمز طول موج کوتاه برخوردار می‌باشد. قدرت تفکیک مکانی این سنجنده با توجه به باندها ۱۰، ۲۰ و ۶۰ متر است. همچنین سنتینل-۲ از توان تفکیک زمانی ۵ روز (با توجه به دو ماهواره آن) برخوردار است (Languille *et al.*, 2017). در این تحقیق از سه باند محدوده مرئی (آبی: ۵۲۲/۵-۴۵۷/۵، سبز: ۵۷۷/۵-۵۴۲/۵ و قرمز: ۶۸۰-۶۵۰ نانومتر) و نیز باند مادون قرمز نزدیک (۸۹۹/۵-۷۸۴/۵ نانومتر) این سنجنده که همگی دارای تفکیک مکانی ۱۰ متر می‌باشد برای محاسبه شاخص‌های طیفی مورد مطالعه، استفاده شد.

برای هر یک از پنج مرحله رشد، بهترین تصویر سنجنده سنتینل-۲ که در دامنه زمانی مرحله مربوطه بوده و از نظر عدم وجود ابر و مه مناسب تشخیص گردیده، انتخاب شد (شکل ۲). تصاویر مربوطه از سایت سازمان زمین‌شناسی آمریکا[1] اخذ شد. پردازش تصاویر این سنجنده و استخراج اطلاعات به‌وسیله نرم‌افزارهای ENVI5.3 و SNAP انجام گردید. همچنین برای انجام عملیات پیش‌پردازش تصاویر همچون تصحیحات اتمسفری[2] از برنامه Sen2Cor استفاده گردید و صحت آن براساس منحنی‌های طیفی سه پدیده گیاه، آب و خاک قابل‌قبول ارزیابی شد. بعد از آن تصویر پیش‌پردازش شده مورد نظر در نرم‌افزار SNAP باز شده و در فرمت استاندارد ENVI ذخیره گردید تا به این طریق، باز شدن تصویر تصحیح شده در نرم‌افزار ENVI5.3 ممکن شود. در ادامه کار، تصویر هر یک از مزارع به‌طور جدا برش داده شد و میزان کمّی هر باند طیفی برای پیکسل‌های هر مزرعه همراه با موقعیت مراکز آن‌ها از طریق نسخه کلاسیک ENVI استخراج شد.

تعیین موقعیت پیکسل‌ها در داخل مزارع و روش نمونه‌برداری

این تحقیق پیکسل‌مبنا بود. لذا تعیین دقیق موقعیت پیکسل‌ها داخل مزارع آزمایشی و متعاقب آن انتخاب مکان نمونه‌برداری درون آن‌ها نقش اساسی در افزایش دقت برآورد عملکرد ایفا می‌کرد. در این تحقیق برای این منظور موارد ذیل رعایت شدند:

– ابتدا با استفاده از اخذ خروجی از تصاویر و مشخص شدن مراکز پیکسل‌های واقع در هر یک از مزارع، به‌وسیله نرم‌افزارهای Excel و AutoCAD مکان شطرنجی پیکسل‌ها و نقشه توزیع آن‌ها مشخص گردید (شکل ۳- الف).

– محدوده شبکه‌ای پیکسل‌های هریک از مزارع با کمک دستگاه سیستم موقعیت‌یابی جهانی سینماتیک زمان واقعی (RTKGPS[3]) دو فرکانسه و با خطای کمتر از ۱۰ سانتی‌متر و با کمک نوار ۱۰۰ متری روی زمین علامت‌گذاری شد. این کار قبل از ساقه رفتن محصول و زمانی که امکان ورود به مزرعه به‌سادگی امکان داشت، انجام گرفت. بعد از آن در طول رشد، چهار گوش پیکسل‌های انتخابی برای اندازه‌گیری، با سنگ، اسپری رنگ و علمک علامت‌گذاری شدند (شکل ۳- ب).

– از هر پیکسل پنج نمونه از چهار گوش و با فاصله مناسب از کناره‌ها، همراه با یک نمونه از مرکز اخذ شد، تا میانگین کل نمونه‌ها به‌عنوان نماینده پیکسل در نظر گرفته شود (شکل ۳- ج).

– نمونه‌برداری از داخل کادر ۱ در ۱ متری میله‌ای انجام گردید (شکل ۳- د).

– موقعیت دقیق مکان نمونه‌ها (مراکز کادرها) بعد از برداشت به‌وسیله دستگاه RTKGPS یادداشت گردید (شکل ۳- ه).

1- Earthexplorer.usgs.gov
2- Atmospheric Correction
3- Real Time Kinematic Global Positioning System



الف- قبل از شروع گل‌دهی: ۹۵/۱۲/۲۴
A. Before flowering: 14.3.2017



ب- ابتدای گل‌دهی: ۹۶/۱/۲۴
B. Early flowering: 13.4.2017



ج- اوج گل‌دهی: ۹۶/۲/۳
C. Peak flowering: 23.4.2017

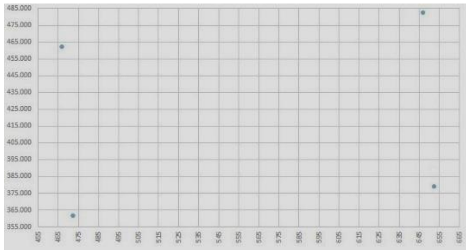


د- رسیدگی سبز: ۹۶/۲/۲۳
D. Green maturity: 13.5.2017



ه- رسیدگی خشک: ۹۶/۳/۲۲
E. Dry maturity: 12.6.2017

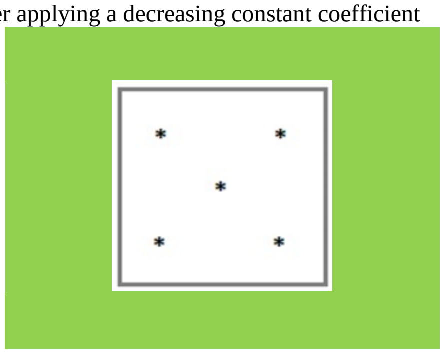
شکل ۲- تاریخ اخذ شده تصاویر سنجنده سنتینل-۲ و عکس‌های متناظر مربوط به پنج مرحله رشد
Fig.2. The date of the Sentinel-2 images and the corresponding pictures of five growing stages



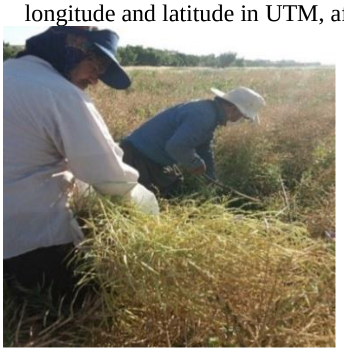
الف- استخراج نقشه توزیع پیکسل‌ها در مزارع؛ مزرعه یک، محور X و Y طول و عرض جغرافیایی بر حسب UTM بعد از اعمال ضریب ثابت کاهشی
A. Extraction of the pixel network of each farm, farm 1, Axis of X and Y are longitude and latitude in UTM, after applying a decreasing constant coefficient



ب- تعیین چهار گوش پیکسل‌ها روی زمین
B. Determination of four pixels corners on farms surface



ج- نمونه‌برداری از پنج نقطه از پیکسل
C. Sampling from five spots from pixel



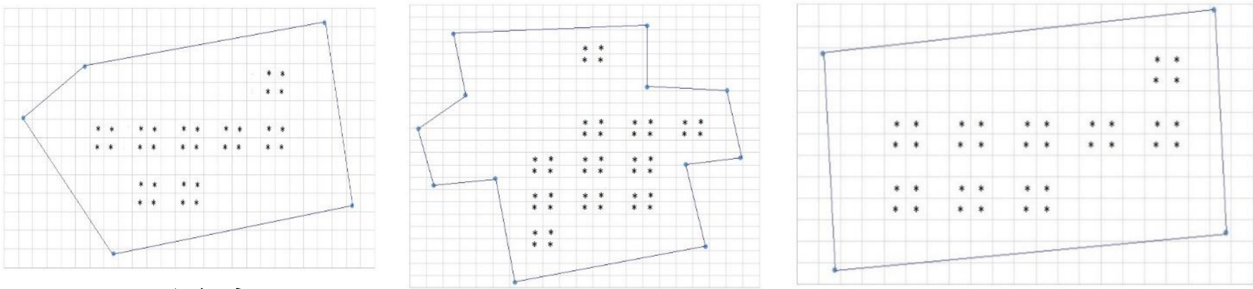
د- نمونه‌برداری مزرعه‌ای از درون کادر میله‌ای
D. Sampling from inside of the frame



ه- تعیین موقعیت دقیق نمونه‌ها با کمک دستگاه RTKGPS
E. Recording exact location of the samples by RTKGPS

شکل ۳- تعیین موقعیت پیکسل‌ها و نمونه‌برداری در مزرعه
Fig.3. Determining of the pixels location and sampling in the experimental farms

از سه مزرعه آزمایشی، ۱۱۲ پیکسل نمونه‌برداری شد که سهم هر یک از مزارع ۱، ۲ و ۳ به‌ترتیب ۳۶، ۴۴ و ۳۲ بود. در این تحقیق پیکسل‌هایی که از حاشیه مزرعه فاصله مناسبی داشتند و با پدیده‌های حاشیه اختلاط نداشتند، انتخاب شدند (شکل ۴). همان‌طور که ذکر شد در این تحقیق برای نمونه‌برداری از کادر ۱ در ۱ متری استفاده شد. بدین شکل در هنگام رسیدگی خشک، محصول درون کادر به‌صورت دستی برداشت گردیده و همراه با کد خاص در داخل گونی قرار داده شد. گونی‌های مربوط به نمونه‌ها بعد از جمع‌آوری از مزارع به آزمایشگاه منتقل گردید و در آنجا بعد از عملیات خشک کردن، عمل کوبش و جدایش صورت گرفت. دانه‌ها باز در معرض آفتاب قرار گرفت و توزین آن‌ها در رطوبت ۱۲-۱۰ درصد انجام شد و در نهایت میانگین نمونه‌های درون هر پیکسل به‌عنوان نماینده عملکرد آن پیکسل مشخص گردید.



الف- مزرعه اول
A. Farm 1

ب- مزرعه دوم
B. Farm 2

ج- مزرعه سوم
C. Farm 3

شکل ٤- محل پیکسل‌های انتخابی برای نمونه‌برداری در مزارع آزمایشی
Fig.4. Location of selected pixels for sampling in experimental farms

شاخص‌های مورد ارزیابی

شاخص‌های زیادی در سنجش از دور براساس ترکیبی از نسبت باندها تعریف شده‌اند که هر کدام در زمینه‌ای همچون تشخیص پوشش گیاهی، تخمین میزان زیست‌توده یا عملکرد و گاه در زمینه‌های تخصصی‌تر همچون برآورد بقایای محصولات و تشخیص خاک‌ورزی حفاظتی از خاک‌ورزی مرسوم نتایج بهتری داشته‌اند. در این تحقیق شاخص‌هایی مورد مطالعه قرار گرفته‌اند که در زمینه زیست‌توده یا عملکرد محصولات زراعی کاربرد بیشتری داشته‌اند. بدین شکل شاخص‌های طیفی متداول و پرکاربرد همچون NDVI و RVI، در کنار شاخص جدیدی همچون NDYI که در مطالعات اخیر در زمینه کلزا مورد توجه قرار گرفته، ارزیابی شده‌اند. در کل ده شاخص طیفی شامل BNDVI، EVI، EVI2، GARI، GNDVI، NDVI، NDYI، MTVI1، MTVI2 و RVI مورد مطالعه قرار گرفته‌اند که تعدادی از آن‌ها همانند EVI، EVI2، MTVI1 و MTVI2 در روابط آن‌ها به جای دو باند، سه باند طیفی دخیل داده شده است (جدول ۱). به‌طور کلی سعی شده است که علاوه بر موارد مذکور، شاخص‌های مورد مطالعه، تمام حوزه‌های طیفی آبی، سبز، قرمز و مادون قرمز را تحت پوشش قرار دهند. به هر حال هر یک از ده شاخص مورد مطالعه با توجه به استخراج باندهای طیفی که در قبل ذکر شد، براساس رابطه آن‌ها که در جدول ۱ آمده است، برای پیکسل‌های مورد ارزیابی محاسبه گردید.

پردازش‌های آماری تحقیق

مبنای آماری پردازش داده‌ها در این تحقیق، مدل‌های رگرسیون ساده و چند متغیره و نیز شبکه عصبی مصنوعی است. یکی از روش‌هایی که می‌توان با آن رابطه بین دو متغیر را محاسبه نمود، رگرسیون ساده است. هدف در مدل رگرسیون ساده رسیدن به یک مدل پیش‌بینی براساس یک متغیر مستقل است (Rezaei and Mirmohammadi, 2011). در بسیاری از مطالعات پیش‌بینی عملکرد محصولات از مدل خطی رگرسیون ساده[1] برای ارزیابی ارتباط عملکرد و هر یک از شاخص‌های گیاهی استفاده شده است (Sulik and Long, 2016; Shanahan *et al.*, 2001; Aparicio *et al.*, 2000). در صورتی که متغیرهای مستقل بیش از یک عامل باشند، مدل رگرسیون چند متغیره به‌کار می‌رود. در این رگرسیون هدف ارزیابی ارتباط بین چند عامل مستقل با یک عامل وابسته است (Sanaeinejad *et al.*, 2014). مدل خطی رگرسیون چند متغیره[2] در برخی مطالعات (Rischbeck *et al.*, 2016; Sanaeinejad *et al.*, 2014) برای پیش‌بینی عملکرد محصولات براساس باندهای ورودی مورد ارزیابی قرار گرفته است. مدل شبکه عصبی نیز در مواردی که ارتباط بین متغیرهای ورودی و خروجی دارای پیچیدگی‌های خاص باشد و یا از روند مشخص و روشنی تبعیت نمی‌کند، کاربرد بیشتری دارد (Kaab *et al.*, 2019). این مدل در برخی از ارزیابی‌های سنجش از دور برای تخمین عملکرد محصولات استفاده شده است (Panda *et al.*, 2010; Li *et al.*, 2007).

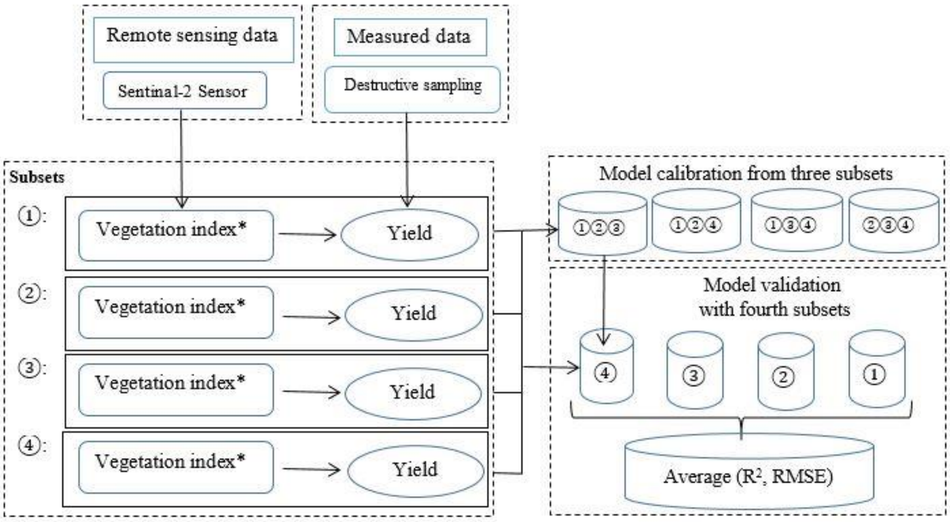
1- Simple Linear Regression Model
2- Multivariate Linear Regression model

جدول ۱- شاخص‌های طیفی مورد مطالعه برای پیش‌بینی عملکرد کلزا در این تحقیق
Table 1- The studied spectral indices for canola yield prediction

شاخص گیاهی Index	اختصار Acronym	رابطه Equation	منبع Reference
شاخص تفاضل پوشش گیاهی نرمال شده آبی Blue Normalized Difference Vegetation Index	BNDVI	(NIR – Blue) / (NIR + Blue)	Sulik and Long, (2016)
شاخص پوشش گیاهی تعدیل شده Enhanced Vegetation Index	EVI	2.5(NIR – Red) / [(NIR + 6Red – 7.5Blue + 1)]	Huete *et al.*, (1996)
شاخص پوشش گیاهی تعدیل شده-۲ 2-band Enhanced Vegetation Index	EVI2	2.5(NIR – Red) / [(NIR + 2.4Red + 1)]	Jiang *et al.*, (2008)
شاخص تفاضل پوشش گیاهی نرمال شده سبزینگی Green Normalization Difference Vegetation Index	GNDVI	(NIR – Green) / (NIR + Green)	Buschmann and Nagel, (1993)
شاخص جوی انعطافی سبزینگی Green Atmospherically Resilient Index	GARI	[NIR – (Green – (Blue – Red))] / [NIR + (Green – (Blue –Red))]	Gitelson *et al.*, (2002)
شاخص تفاضل پوشش گیاهی نرمال شده Normalization Difference Vegetation Index	NDVI	(NIR – Red) / (NIR + Red)	Rouse *et al.*, (1974)
شاخص تفاضل نرمال شده زردی Normalized Difference Yellowness Index	NDYI	(Green−Blue) / (Green + Blue)	Sulik and Long, (2016)
شاخص پوشش گیاهی اصلاح شده سه‌گانه-۱ Modified Triangular Vegetation Index 1	MTVI1	1.2[1.2(NIR-G)-2.5(Red-G)]	Haboudane *et al.*, (2004)
شاخص پوشش گیاهی اصلاح شده سه‌گانه-۲ Modified Triangular Vegetation Index 2	MTVI2	$[1.8(NIR\text{-}G)\text{-}3.75(Red\text{-}G)] / [[(2NIR+1)^2\text{-}(6NIR\text{-}5(Red)^{0.5}) – 0.5]^{0.5}$	Haboudane *et al.*, (2004)
شاخص نسبت پوشش گیاهی Ratio Vegetation Index	RVI	NIR / Red	Birth and McVey, (1968)

در این تحقیق برای تعیین توانایی هر یک از شاخص‌های مورد مطالعه به‌منظور تخمین عملکرد کلزا از رگرسیون ساده استفاده گردید. بدین شکل در هر مرحله رشد، هر شاخص طیفی به‌طور جداگانه به‌عنوان متغیر مستقل و عملکرد کلزا به‌عنوان متغیر وابسته در نظر گرفته شد. همچنین در رگرسیون چند متغیره و نیز شبکه عصبی، متغیرهای مستقل (ورودی‌ها) شامل چهار باند، سه باند مرئی و باند مادون قرمز نزدیک، بوده و متغیر وابسته (خروجی)، عملکرد کلزا می‌باشد. نتیجه رگرسیون چند متغیره تعیین یک رابطه بین باندها معادل شاخص‌های طیفی است. این رابطه ترکیبی از باندها که بیشترین میزان همبستگی با عملکرد دارد را نشان می‌دهد. برای اعمال رگرسیون چند متغیره از روش گام به گام[1] استفاده شد. موقعی رگرسیون گام به گام به‌کار می‌رود که هدف نشان دادن سهم هر یک از متغیرهای مستقل در پیش‌بینی متغیر وابسته باشد و نیز تعیین این که در کل این متغیرها چقدر می‌توانند متغیر وابسته را پیش‌بینی نمایند (Sanaeinejad *et al.*, 2014). برای محاسبات رگرسیون از نرم‌افزار Minitab استفاده گردید. همچنین در این پژوهش برای پیاده‌سازی شبکه عصبی از یک شبکه پرسپترون چندلایه (MLP[2]) که اصولاً از یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی تشکیل یافته، استفاده شده است. برای آموزش این شبکه، معمولاً از الگوریتم پس‌انتشار (BP[3]) استفاده می‌شود. در طی آموزش شبکه MLP به کمک الگوریتم یادگیری BP (پس انتشار)، ابتدا محاسبات از ورودی شبکه به‌سوی خروجی شبکه انجام می‌شود و سپس مقادیر خطای محاسبه شده به لایه‌های قبل انتشار می‌یابد. در ابتدا، محاسبه خروجی به‌صورت لایه به لایه انجام می‌شود و خروجی هر لایه، ورودی لایه بعدی خواهد بود. در حالت پس‌انتشار، ابتدا لایه‌های خروجی تعدیل می‌شود، زیرا برای هر یک از نرون‌های لایه خروجی، مقدار مطلوبی وجود دارد و می‌توان به کمک آن‌ها و قاعده‌های به هنگام‌سازی، وزن‌ها را تعدیل نمود (Kaab *et al.*, 2019).

1- Stepwise
2- Multi-Layer Perceptron
3- Back Propagation



* در رگرسیون ساده هر یک از شاخص‌های گیاهی و در رگرسیون چند متغیره چهار باند به‌عنوان ورودی در نظر گرفته شدند.

*In simple regression, each of vegetation indices and in multivariate regression, four bands, were as inputs.

شکل ۵– دیاگرام اعتبارسنجی متقاطع چند بخشی

Fig.5. Diagram of cross validation; K-Fold

در این تحقیق برای اعتبارسنجی مدل‌های رگرسیون ساده و چند متغیره از روش اعتبارسنجی متقاطع[1] چند بخشی[2] استفاده گردید. براساس این روش داده‌ها به چهار دسته تقسیم شدند و در هر بار، سه دسته به‌عنوان آموزش و دسته چهارم برای اعتبارسنجی استفاده گردید و اعتبارسنجی نهایی براساس میانگین چهار بار اعتبارسنجی محاسبه گردید (شکل ۵). همچنین برای پردازش مدل‌های شبکه عصبی از نرم‌افزار MATLAB استفاده گردید و تقسیم‌بندی داده‌های آن براساس ۷۰ درصد برای آموزش، ۱۵ درصد برای اعتبارسنجی و ۱۵ درصد برای آزمون انجام شد.

ضریب تبیین (R^2) و ریشه میانگین مربعات خطا (RMSE[3]) دو آماره‌ای که به‌عنوان معیارهای ارزیابی روابط به‌دست آمده، مورد استفاده قرار گرفتند. این آماره‌ها در روابط (۱) و (۲) ارائه شده است. در این روابط n تعداد نمونه‌ها، Pi و Ai به‌ترتیب میزان عملکرد پیش‌بینی شده و واقعی برای هر پیکسل و $\bar{A}$ میزان متوسط عملکردهای واقعی می‌باشد. یادآور می‌شود تعداد نمونه‌ها در این روابط برابر با ۱۱۲ پیکسل مورد ارزیابی است.

$$R^2 = 1 - \left(\frac{\sum_{i=1}^{n}(P_i - A_i)^2}{\sum_{i=1}^{n}(A_i - \bar{A})^2}\right) \qquad (۱)$$

$$RMSE = \sqrt{\frac{1}{n}\sum (P_i - A_i)^2} \qquad (۲)$$

1- Cross validation
2- K-Fold
3- Root Mean Square Error

نتایج و بحث

نتایج تجزیه ده شاخص مورد مطالعه به‌وسیله رگرسیون ساده نشان داد که میزان همبستگی هر یک از این شاخص‌ها با عملکرد کلزا در مراحل مختلف رشد تفاوت قابل‌توجهی دارد. بدین ترتیب ضریب تبیین شاخص NDYI در مرحله قبل از گل‌دهی، خیلی ضعیف (۲۰-۰ درصد)، در مراحل رسیدگی سبز و رسیدگی خشک، ضعیف (۴۰-۲۱ درصد)، در مرحله ابتدای گل‌دهی، متوسط (۶۰-۴۱ درصد)، و در مرحله اوج گل‌دهی، خوب (۸۰-۶۱ درصد) بوده است. این ضریب برای شاخص NDVI در مرحله رسیدگی سبز، متوسط و در بقیه مراحل، ضعیف، به‌دست آمده است. همچنین ضریب تبیین برای شاخص EVI در مرحله قبل از گل‌دهی، ضعیف، در مرحله رسیدگی سبز، متوسط و در مراحل ابتدای گل‌دهی، اوج گل‌دهی و رسیدگی خشک، خیلی ضعیف ارزیابی شده است. این ضریب برای شاخص BNDVI در مرحله قبل از گل‌دهی، خیلی ضعیف، در مرحله رسیدگی خشک، ضعیف، در مراحل ابتدای گل‌دهی و رسیدگی سبز، متوسط و در مرحله اوج گل‌دهی، خوب بوده است. ضریب تبیین سایر شاخص‌ها در مرحله قبل از گل‌دهی، همگی ضعیف و در مرحله ابتدای گل‌دهی، به‌جز شاخص MTVI1 که در دامنه متوسط و شاخص MTVI2 که در دامنه ضعیف قرار گرفته‌اند، خیلی ضعیف بوده است. همچنین ضریب تبیین این شاخص‌ها در مرحله اوج گل‌دهی، به‌جز شاخص MTVI1 که در دامنه متوسط و شاخص‌های MTVI2 و EVI2 که در دامنه ضعیف قرار گرفته‌اند، بقیه خیلی ضعیف به‌دست آمده و در مرحله رسیدگی سبز، ضریب تبیین این شاخص‌ها متوسط بوده است.

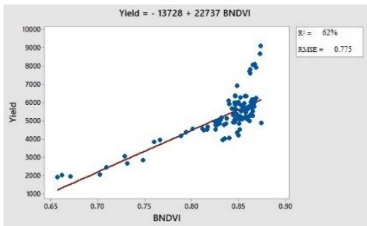
این شاخص‌ها از نظر ضریب تبیین در مرحله رسیدگی خشک، بـه‌جـز شاخص GNDVI و GARI که ضـعیف بـوده، بقیـه خیلـی ضـعیف ارزیابی شده‌اند (جدول ۲).

جدول ۲- ضریب تبیین (R^2) و ریشه میانگین مربعات خطا (RMSE) برای شاخص‌های مورد ارزیابی در مراحل مختلف رشد کلزا

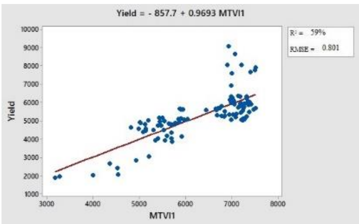
Table 2- Determination coefficient (R^2) and Root Mean Square Error (RMSE) for evaluated spectral indices in different stages of growth

شاخص Index	قبل از گل‌دهی **Before flowering**		ابتدای گل‌دهی **Early flowering**		اوج گل‌دهی **Peak flowering**		رسیدگی سبز **Green maturity**		رسیدگی خشک **Dry maturity**	
	R^2 (%)	RMSE ($ton.ha^{-1}$)	R^2 (%)	RMSE ($ton.ha^{-1}$)	R^2 (%)	RMSE ($ton.ha^{-1}$)	R^2 (%)	RMSE ($ton.ha^{-1}$)	R^2 (%)	RMSE ($ton.ha^{-1}$)
BNDVI	15	1.158	52	0.869	62	0.775	41	0.965	33	1.029
EVI	28	1.068	5	1.231	2	1.251	50	0.888	12	1.179
EVI2	24	1.096	20	1.128	22	1.106	53	0.866	20	1.129
GARI	25	1.091	10	1.195	6	1.219	43	0.948	31	1.045
GNDVI	23	1.102	16	1.152	12	1.176	44	0.937	35	1.014
NDVI	23	1.101	21	1.119	24	1.095	56	0.831	21	1.117
NDYI	2	1.249	45	0.929	73	0.652	32	1.038	24	1.097
MTVI1	28	1.069	41	0.962	59	0.801	42	0.956	8	1.203
MTVI2	21	1.119	26	1.082	32	1.037	49	0.897	18	1.142
RVI	29	1.061	17	1.148	16	1.154	51	0.882	17	1.149

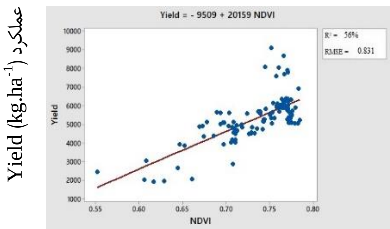
با توجه به مقایسه ضرایب تبیین به‌دست آمـده، بیشـترین میـزان همبستگی شاخص‌های طیفی مورد مطالعه با عملکرد کلـزا بـه‌ترتیـب متعلق به NDYI در مرحله اوج گل‌دهی بـا ۷۳ درصـد، BNDVI در مرحله اوج گل‌دهی با ۶۲ درصد، MTVI1 در مرحله اوج گل‌دهی بـا ۵۹ درصد، NDVI در مرحله رسیدگی سـبز بـا ۵۶ درصـد، EVI2 در مرحله رسیدگی سبز با ۵۳ درصد، BNDVI در مرحله ابتدای گل‌دهی با ۵۲ درصد و RVI در مرحله رسیدگی سبز با ۵۱ درصد بـود (شـکل ۶).



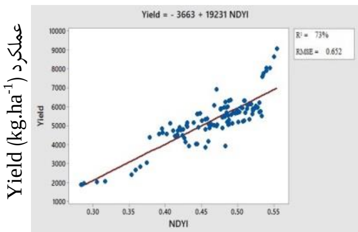
الف- BNDVI در مرحله اوج گل‌دهی
A. BNDVI in peak flowering



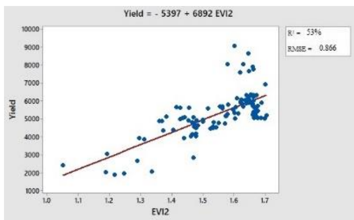
ب- MTVI1 در مرحله اوج گل‌دهی
B. MTVI1 in peak flowering



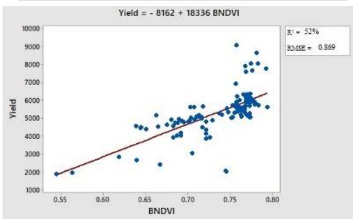
ج- NDVI در مرحله رسیدگی سبز
C. NDVI in green maturity



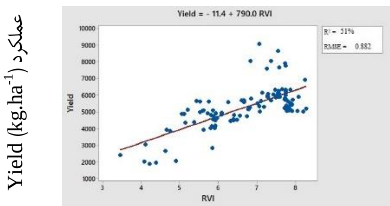
د- NDYI در مرحله اوج گل‌دهی
D. NDYI in peak flowering



ه- EVI2 در مرحله رسیدگی سبز
E. EVI2 in green maturity



و- BNDVI در مرحله ابتدای گل‌دهی
F. BNDVI in early flowering

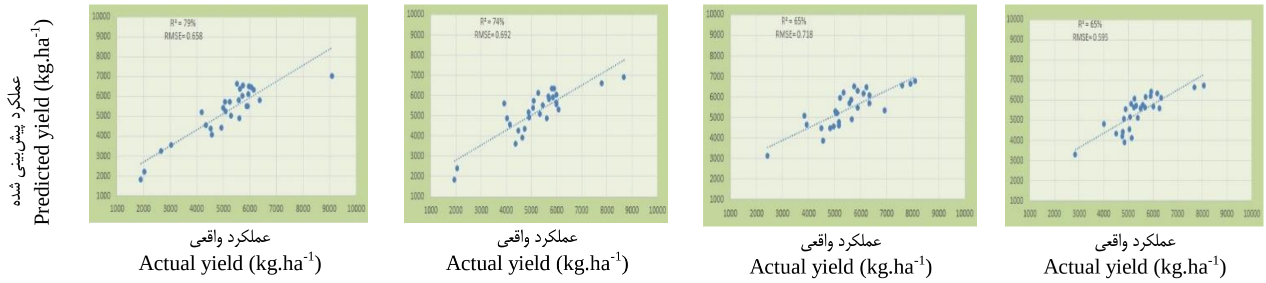


ز- RVI در مرحله رسیدگی سبز
G. RVI in green maturity

شکل ٦- مدل‌های رگرسیون ساده بین عملکرد کلزا و شاخص‌هایی که ضریب تبیین (R^2) بالاتر از ۵۰٪ کسب کرده‌اند

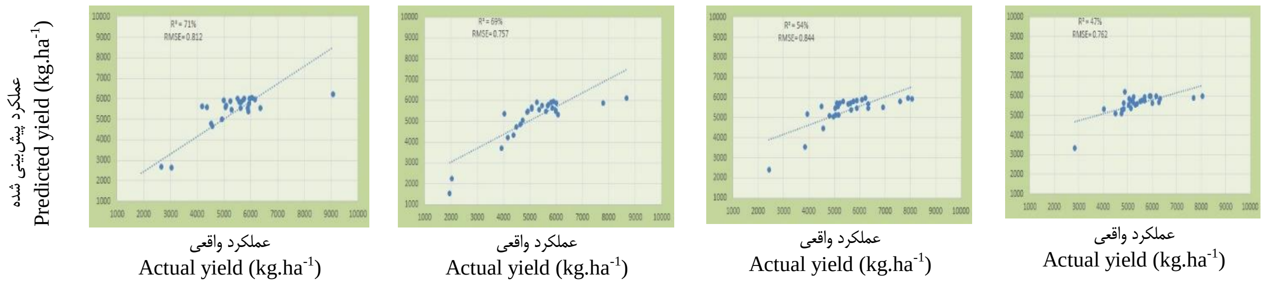
Fig.6. Simple regression models between canola yield and indices with determination coefficient (R^2) more than 50% recorded

نتایج اعتبارسنجی دو شاخص NDYI و BNDVI در مرحله اوج گل‌دهی که میزان همبستگی آن‌ها با عملکرد در سطح خوب بوده، به‌ترتیب ۷۱ و ۶۰ درصد و RMSE آن‌ها به میزان ۰/۶۶۶ و ۰/۷۹۴ بود. این نتایج، میانگین چهار بار اعتبارسنجی رگرسیون ساده طبق روش اعتبارسنجی متقاطع چند بخشی بوده است (شکل ۷).



الف– NDYI در مرحله اوج گل‌دهی

A- NDYI in peak flowering



ب– BNDVI در مرحله اوج گل‌دهی

B- BNDVI in peak flowering

شکل ۷– اعتبارسنجی متقاطع رگرسیون ساده به روش چند بخشی برای شاخص‌های دارای بیشترین میزان همبستگی

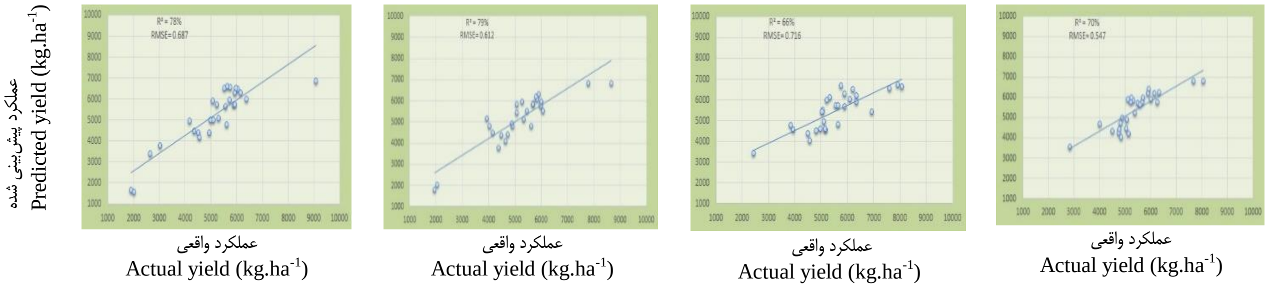
Fig.7. Cross validation, K-Fold, of simple regression for indices with highest correlation recorded

همان‌طور که گفته شد در این مطالعه علاوه بر رگرسیون ساده، رگرسیون چند متغیره با ورودی‌های چهار باند، سه باند مرئی و باند مادون قرمز نزدیک، مورد ارزیابی قرار گرفت. این کار برای پنج مرحله رشد به‌طور جداگانه و در سطح احتمال ۵ درصد انجام شد. نتایج این رگرسیون نشان داد که بهترین ترکیب باندی در مرحله اوج گل‌دهی با ضریب تبیین ۷۶ درصد می‌باشد (جدول ۳). در این رگرسیون ترکیب باندها در مرحله رسیدگی سبز نیز با ضریب تبیین ۶۲ درصد در دامنه خوب قرار گرفت و سایر مراحل متوسط یا ضعیف بودند (جدول ۳). نتایج اعتبارسنجی این رگرسیون در دو مرحله اوج گل‌دهی و رسیدگی سبز به‌ترتیب ۷۳ و ۵۹ درصد و RMSE آن‌ها ۰/۶۴۱ و ۰/۸۰۱ بود. این نتایج میانگین چهار بار اعتبارسنجی رگرسیون چند متغیره طبق روش اعتبارسنجی متقاطع چند بخشی بوده است (شکل ۸).

جدول ۳– ضریب تبیین (R^2) و ریشه میانگین مربعات خطا (RMSE) در رگرسیون چند متغیره برای چهار باند به‌عنوان ورودی

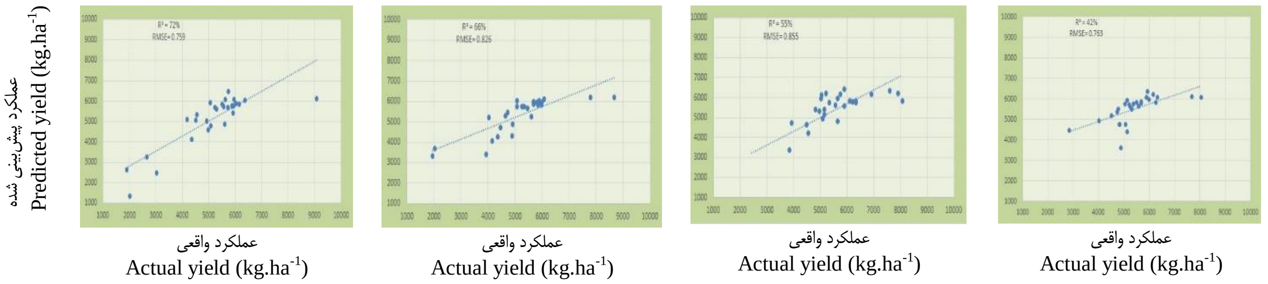
Table 3- Determination coefficient (R^2) and Root Mean Square Error (RMSE) in multivariate linear regression model for four bands as inputs

Stage مرحله	R^2 (%)	RMSE (ton.ha^{-1})	Equation رابطه
قبل از گل‌دهی Before flowering	34	1.011	Yield = 650 + 2.94 Green + 0.504 NIR
ابتدای گل‌دهی Early flowering	55	0.841	Yield = 3177 - 6.66 Blue + 1.250 Green + 1.091 NIR
اوج گل‌دهی Peak flowering	76	0.622	Yield = 3976 - 14.432 Blue + 6.360 Green
رسیدگی سبز Green maturity	62	0.778	Yield = 8459 + 5.25 Green - 12.271 Red
رسیدگی خشک Dry maturity	39	0.981	Yield = 8746 - 2.560 Green



الف- مرحله اوج گل‌دهی

A. Stage of peak flowering



ب- مرحله رسیدگی سبز

B. Stage of green maturity

شکل ۸- اعتبارسنجی متقاطع رگرسیون چند متغیره به روش چند بخشی برای مراحل دارای بیشترین میزان همبستگی

Fig.8. Cross validation, K-Fold, of the multivariate regression for stages with highest correlation recorded

در این تحقیق علاوه بر مدل‌های رگرسیونی، مدل شبکه عصبی نیز مورد ارزیابی قرار گرفت. این کار برای پنج مرحله رشد به‌طور جداگانه انجام شد. به‌منظور دستیابی به بهترین ساختار شبکه عصبی، تعداد مختلفی از ساختارها با یک و دولایه مخفی و با تعداد نرون‌های یک تا ۳۰ در لایه‌های مخفی، آزمون و اعتبارسنجی شده‌اند و همچنین در این تحقیق از بین الگوریتم‌های آموزش، الگوریتم آموزش لونبرگ - مارکوات[1] انتخاب گردید. نتایج حاصل از اجرای شبکه عصبی برای پنج مرحله رشد در جدول ۴ ارائه شده است. همان‌طور که در این جدول مشاهده می‌شود بهترین نتیجه در همه مراحل رشد با دو لایه مخفی اما با تعداد نرون‌های متفاوت در هر لایه به‌دست آمد. نتایج این ارزیابی نشان داد که براساس ضریب تبیین در هر دو مرحله آموزش و آزمون، بهترین مدل شبکه عصبی در مرحله اوج گل‌دهی رقم خورد. همچنین بعد از این مرحله، به‌ترتیب مراحل رسیدگی سبز، ابتدای گل‌دهی و رسیدگی خشک نتایج بهتری کسب کردند و مرحله قبل از گل‌دهی از این لحاظ ضعیف‌ترین مدل پیش‌بینی را کسب نمود. نتایج ارزیابی شبکه عصبی در مرحله اوج گل‌دهی نشان داد که ساختار ۱-۸-۱۵-۴ با چهار ورودی، دو لایه مخفی با ۱۵ و ۸ نرون مخفی و یک پارامتر خروجی، به‌عنوان بهترین ساختار تعیین شده است (شکل ۹). برای این ساختار ضریب تبیین و RMSE به‌ترتیب برابر با ۹۲ درصد و ۰/۴۶۱ برای مرحله آموزش و ۷۷ درصد و ۰/۶۱۲ برای مرحله آزمون به‌دست آمد (جدول ۴). در شکل ۱۰ توزیع نقاط و ضریب همبستگی (R) بین مقادیر پیش‌بینی‌شده و واقعی عملکرد برای این مدل در مرحله اوج گل‌دهی ارائه شده است.

رنگ پوشش گیاهی کلزا در هنگام گل‌دهی از سبز به زرد تبدیل می‌شود و میزان تراکم رنگ زرد در اوج گل‌دهی به بیشترین میزان خود می‌رسد. سپس با تبدیل گل‌ها به غلاف باز رنگ پوشش گیاهی به سبز برمی‌گردد. دو پوشش گیاهی زرد، در هنگام اوج گل‌دهی و سبز، در هنگام تشکیل کامل غلاف‌ها در زمان رسیدگی سبز، هر دو در شرایط اوج تراکم محصول از نظر زیست‌توده و حجم بوته رخ می‌دهند (شکل ۲ج و د). از آن‌جایی که میزان پوشش گیاهی و زیست‌توده از یک جانب ارتباط مستقیمی در میزان بازتاب طیف‌های نوری و در نتیجه در میزان شاخص‌های گیاهی دارد و از جانب دیگر میزان عملکرد متاثر از میزان زیست‌توده می‌باشد (Jin *et al.*, 2016; Clevers *et al.*, 2007)، نتایج به‌دست آمده دال بر این که دو مرحله اوج گل‌دهی و رسیدگی سبز کلزا بیشترین میزان همبستگی با عملکرد را کسب کرده‌اند، دارای قوت بالایی به نظر می‌رسد. حال در جواب سئوال: "از بین دو مرحله اوج گل‌دهی و رسیدگی سبز کدام یک همبستگی بیشتری با عملکرد می‌تواند داشته باشد؟"، احتمالاً نوع محصول و نیز مدل و شاخصی که پیاده‌سازی می‌گردد، نقش کلیدی

1- Levenberg-Marquardt

در جواب دارد. انتظار می‌رود شاخص‌هایی که در بسیاری از محصولات سبز، نقش پر رنگ‌تری در تخمین عملکرد داشته‌اند، در مرحله اوج گل‌دهی و رنگ زرد پوشش گیاهی کلزا نتوانند همان توانایی را داشته باشند. نتایج این تحقیق نیز نشان می‌دهد که در مرحله اوج گل‌دهی شاخص‌هایی همچون NDVI و RVI ضرایب تبیین کمتری نسبت به دو شاخص NDYI و BNDVI کسب کرده‌اند. مطالعات صورت گرفته براساس طیف‌سنجی زمینی توسط Sulik and Long (2016) نیز نشان داد در مرحله اوج گل‌دهی دو شاخص NDYI و BNDVI بیشترین همبستگی با عملکرد کلزا داشتند. در مطالعه مذکور در مورد اهمیت باند آبی در پوشش گیاهی زرد کلزا شرح کاملی آمده است. بدین شکل که رنگ زرد حاصل جمع بازتاب سبز و قرمز است. گلبرگ‌های کلزا رنگ آبی را جذب کرده و از رنگ‌های مرئی فقط سبز و قرمز بازتاب می‌شود که به شکل زرد مشاهده می‌شود. در واقع تفاوت دو شاخص NDYI و BNDVI با سایر شاخص‌ها در کم شدن باند Blue در روابط هر دوی آن‌ها است (جدول ۱). براساس این دو رابطه، در مرحله اوج گل‌دهی، بازتاب باند آبی که متعلق به سایر اجزا از جمله ساقه‌ها و برگ‌ها است، از باند دیگر روابط دو شاخص NDYI و BNDVI کم می‌شود و لذا این دو شاخص تا جایی که امکان هست، در جهت نمایندگی گلبرگ‌ها پیش می‌روند. اما در این زمینه سایر اجزا (ساقه‌ها و برگ‌ها) در بازتاب باند دیگر این دو شاخص (در Green در رابطه NDYI و در NIR در رابطه BNDVI) با گلبرگ‌ها هم‌پوشانی دارند و لذا دقت پیش‌بینی کمتر می‌شود. البته تمام گلبرگ‌ها به غلاف و دانه تبدیل نمی‌شوند و این باز در کاهش دقت تاثیر خود را دارد. به هر حال این تحلیل وقتی قوت بیشتری می‌گیرد که در رابطه به‌دست آمده از ترکیب باندی رگرسیون چند متغیره در مرحله اوج گل‌دهی، باز ضریب باند آبی منفی است و از سایر اجزا رابطه کم می‌شود (جدول ۳).

مطالعات Sulik and Long (2016) و نیز Zhang and He, (2013) نشان داد که با توجه به طیف‌سنجی صورت گرفته، در بین مراحل رشد، بیشترین میزان همبستگی برای تخمین عملکرد کلزا در مرحله اوج گل‌دهی به‌دست می‌آید. در مطالعه حاضر نیز براساس نتایج رگرسیون ساده بیشترین ضریب تبیین برای تخمین عملکرد کلزا متعلق به شاخص NDYI در مرحله اوج گل‌دهی می‌باشد (جدول ۲) و همچنین نتیجه رگرسیون چند متغیره و نیز شبکه عصبی نشان دادند که بهترین نتیجه برای برآورد عملکرد کلزا در مرحله اوج گل‌دهی رخ داد (جدول ۳).

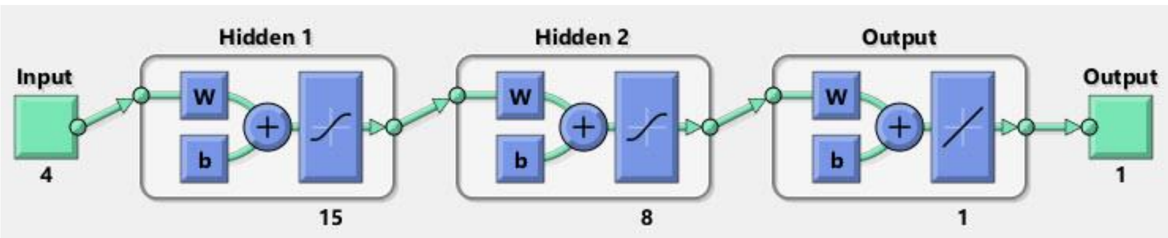
جدول ٤- نتایج شبکه عصبی برای مدل‌سازی عملکرد کلزا در مراحل مختلف رشد

Table 4- Neural network result for modeling canola yield in different growth stages

Stage مرحله	Layer لایه		Training آموزش		Test آزمون	
	NH1*	NH2**	R^2 (%)	RMSE ($ton.ha^{-1}$)	R^2 (%)	RMSE ($ton.ha^{-1}$)
قبل از گل‌دهی Before flowering	16	7	59	0.801	41	0.962
ابتدای گل‌دهی Early flowering	16	9	83	0.553	61	0.785
اوج گل‌دهی Peak flowering	15	8	92	0.461	77	0.612
رسیدگی سبز Green maturity	14	8	89	0.493	70	0.682
رسیدگی خشک Dry maturity	18	8	65	0.741	60	0.793

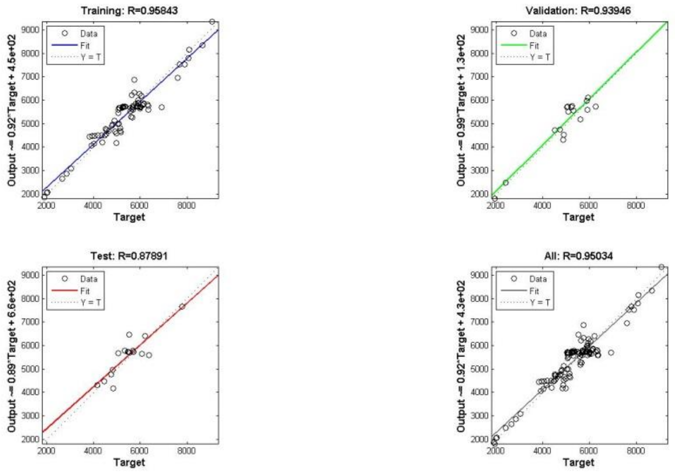
* تعداد نرون‌های لایه مخفی اول: Number of neurons in layar-1

** تعداد نرون‌های لایه مخفی دوم: Number of neurons in layar-2



شکل ۹- ساختار شبکه عصبی در مرحله اوج گل‌دهی

Fig.9. Neural network topology at flowering stage



شکل ۱۰– ضریب همبستگی (R) بین مقادیر پیش‌بینی‌شده و واقعی عملکرد برای آموزش، آزمون، اعتبارسنجی و کل مدل در اوج گل‌دهی

Fig.10. Correlation coefficient (R) between predicted and actual yield for training, testing, validation and total calibration at peak of flowering

نتایج مطالعاتی که عملکرد کلزا را در مراحل مختلف رشد بررسی کرده‌اند (Dominguez *et al.*, 2017; Piekarczyk, 2011)، نشان داده است که همبستگی شاخص NDVI با عملکرد در مرحله اوج گل‌دهی نسبت به زمان رسیدگی سبز کمتر است. این مسأله در نتیجه تحقیق حاضر نیز مشاهده می‌شود به‌طوری که ضریب تبیین برای این شاخص ۲۴ درصد در مرحله اوج گل‌دهی در مقابل ۵۶ درصد در مرحله رسیدگی سبز می‌باشد (جدول ۲).

در مقایسه تخمین عملکرد گندم و کلزا به‌وسیله شاخص‌های گیاهی (Basnyat *et al.*, 2004)، نتایج همبستگی شاخص NDVI با عملکرد کلزا نسبت به گندم پایین‌تر گزارش شده و کم بودن این همبستگی به پوشش گیاهی زرد کلزا نسبت داده شده است. در تحقیق حاضر نیز نتایج همبستگی NDVI با عملکرد کلزا در مرحله اوج گل‌دهی از شاخص‌های دیگر همچون NDYI و BNDVI بسیار کمتر است و این نتیجه می‌تواند متأثر از پوشش گیاهی زرد آن باشد.

در مرحله رسیدگی سبز بیشترین ضرایب تبیین به‌ترتیب به NDVI، EVI2 و RVI تعلق داشت (جدول ۲). شاخص NDVI شاخص متداول پوشش گیاهی در تعیین زیست‌توده و عملکرد می‌باشد که در بسیاری از محصولات سبز نتایج بهتری نسبت به سایر شاخص‌ها کسب کرده است و در این تحقیق بیشترین ضریب تبیین در مرحله سبز را کسب نموده است. همچنین در تخمین عملکرد کلزا در جنوب غربی استان خوزستان این شاخص بعد از شاخص GNVI بیشترین ضریب تبیین را کسب نموده است (Zahirnia *et al.*, 2016). البته مطالعه مذکور با استفاده از تصاویر لندست-۸ و براساس بررسی مزارع مختلف انجام گردیده است. به‌طور مشخص ارتباط شاخص EVI2 با عملکرد کلزا در مطالعات سنجش از دور گزارش نشده است اما در مورد شاخص EVI که اساس رابطه آن همانند شاخص EVI2 است (جدول ۲)، این شاخص نتایج مشابه با شاخص NDVI در پیش‌بینی عملکرد کلزا کسب کرد. به‌طوری‌که نتایج سنجنده مودیس با دوره ۱۶ روزه و وضوح ۲۵۰ متری نشان داد که ضریب تبیین این دو شاخص در برآورد عملکرد کلزا ۳۵ و ۳۳ درصد به‌ترتیب برای EVI و NDVI می‌باشد (Johnson, 2016). در مطالعه حاضر نیز شاخص‌های NDVI، EVI2 و EVI به‌ترتیب با کسب ضرایب تبیین ۵۶، ۵۳ و ۵۰ درصد، نتایج مشابهی کسب کرده‌اند. البته تفاوت مقادیر نتایج مطالعه حاضر با مطالعه مذکور می‌تواند به نوع سنجنده و خصوصاً تفاوت قابل‌توجه وضوح آن‌ها مرتبط باشد. شاخص RVI نیز که در مرحله سبز نتایج خوبی کسب کرده است، شاخصی است که نتایج آن در برخی مطالعات محصولات سبز بهتر از سایر شاخص‌ها گزارش شده است. در این زمینه بیشترین میزان همبستگی با محصول گندم دوروم (Aparicio *et al.*, 2000)، و نیز بیشترین میزان همبستگی با ذرت (Shanahan *et al.*, 2001) توسط این شاخص گزارش شده است. همچنین در برآورد عملکرد کلزا با استفاده از تصاویر ماهواره لندست-۸، این شاخص بعد از شاخص NDYI، بیشترین ضریب تبیین را کسب نموده است (Loveimi *et al.*, 2019).

از نتایج دیگر این پژوهش شباهت ترتیب مراحل رشد از نظر میزان همبستگی با عملکرد کلزا در مدل‌های چند متغیره و شبکه عصبی است؛ به‌طوری که در هر دوی این ارزیابی‌ها، مرحله اوج گل‌دهی بیشترین همبستگی با عملکرد را کسب نمود و همچنین بعد از این مرحله، به‌ترتیب مراحل رسیدگی سبز، ابتدای گل‌دهی، رسیدگی خشک و قبل از گل‌دهی قرار گرفتند. به نظر می‌رسد این نتیجه

مشترک دو مدل با میزان حجم پوشش گیاهی و زیست‌توده مرتبط است. در واقع همان‌طور که گفته شد در مرحله اوج گل‌دهی و نیز رسیدگی سبز بیشترین تراکم پوشش گیاهی و زیست‌توده وجود دارد و همبستگی بیشتر این دو مرحله قابل انتظار بود. همچنین همان‌طور که بحث شد کلزا به‌دلیل پوشش گیاهی زرد آن، بهترین زمان پیش‌بینی عملکرد آن در مرحله اوج گل‌دهی اتفاق افتاده است. مراحل دیگر رشد نیز با توجه به میزان زیست‌توده آن‌ها، از همبستگی متفاوتی برخوردار بودند؛ به‌طوری که مرحله قبل از گل‌دهی با توجه به حداقل زیست‌توده و پوشش گیاهی کمترین همبستگی را کسب نمود.

نتیجه‌گیری

نتایج این تحقیق نشان داد براساس ارزیابی‌های شاخص‌های مختلف طیفی با استفاده از مدل رگرسیون ساده، بیشترین میزان همبستگی با عملکرد کلزا توسط شاخص جدید NDYI در مرحله اوج گل‌دهی کسب گردید. همچنین براساس ارزیابی مدل رگرسیون چند متغیره، بهترین ترکیب باندی در مرحله اوج گل‌دهی رخ داد. در رابطه شاخص NDYI و نیز ترکیب باندی مرحله اوج گل‌دهی مدل رگرسیون چند متغیره، ضریب باند آبی (Blue)، منفی می‌باشد. در واقع در مرحله اوج گل‌دهی، گلبرگ‌های زرد کلزا باند آبی را جذب می‌کنند و در نتیجه بازتاب باند آبی منتج از پوشش گیاهی محصول در این مرحله، متعلق به سایر اجزا از جمله ساقه‌ها و برگ‌ها است؛ لذا با کم شدن آن (داشتن ضریب منفی)، مدل‌ها و روابط، هرچه بیشتر در جهت نمایندگی گلبرگ‌ها پیش می‌روند. در نتیجه از آن‌جایی که میزان گلبرگ‌ها با میزان غلاف و دانه استحصالی رابطه مستقیم دارد، همبستگی با عملکرد بهبود یافت. علاوه بر این، در ارزیابی مدل شبکه عصبی نیز بیشترین میزان همبستگی با عملکرد کلزا در مرحله اوج گل‌دهی به‌دست آمد. همچنین در هر دو ارزیابی مدل‌های رگرسیون چند متغیره و شبکه عصبی، بعد از مرحله اوج گل‌دهی، به‌ترتیب مراحل رسیدگی سبز، ابتدای گل‌دهی، رسیدگی خشک و قبل از گل‌دهی بیشترین میزان همبستگی با عملکرد را کسب کردند.

پیشنهادها

براساس نتایج این تحقیق، گل‌های کلزا و پوشش گیاهی زرد آن نقش مهمی در پیش‌بینی عملکرد دارد. پیشنهاد می‌شود به‌وسیله دوربین‌های رقومی و سنجنده‌های مستقر بر پهباد، روند توسعه گل‌ها و پوشش زرد کلزا به‌صورت روزانه رصد شود و این روند با میزان عملکرد کلزا در پیکسل‌ها و یا مزارع متفاوت ارزیابی گردد. همچنین این پژوهش براساس به‌کارگیری سنجنده نوری (طیفی) سنتینل-۲ صورت گرفت؛ پیشنهاد می‌شود سنجنده‌های راداری و نیز ترکیب آن‌ها با سنجنده‌های نوری برای پیش‌بینی عملکرد کلزا مطالعه شود.

References

1. Ahamed, T., L. Tian, Y. Zhang, and K. C. Ting. 2011. A review of remote sensing methods for biomass feedstock production. Biomass and Bioenergy 35: 2455-2469.
2. Alavipanah, S. K. 2016. Fundamentals of modern remote sensing and interpretation of Satellite images and aerial photos. University of Tehran. Tehran. (In Farsi).
3. Alizadeh Rabie, H. 2014. Remote Sensing (Principles and Application). Samt Press. Tehran.
4. Aparicio, N., D. Villegas, J. Casadesus, J. L. Araus, and C. Royo. 2000. Spectral vegetation indices as nondestructive tools for determining durum wheat yield. Agronomy Journal 92 (1): 83-91.
5. Ash, M. 2017. Canola Production and Processing. Available at: https://www.ers.usda.gov/topics/crops/soybeans-oil-crops/canola.aspx. Accessed 27 March 2018.
6. Basnyat, P., B. McConkey, G. P. Lafond, A. Moulin, and Y. Pelcat. 2004. Optimal time for remote sensing to relate to crop grain yield on the Canadian prairies. Canadian Journal of Plant Science 84 (1): 97-103.
7. Birth, G. S., and G. R. McVey. 1968. Measuring color of growing turf with a reflectance spectrophotometer. Agronomy Journal 60: 640-649.
8. Boschetti, M., S. Bocchi, and P. A. Brivio. 2007. Assessment of pasture production in the Italian Alps using spectrometric and remote sensing information. Agriculture, Ecosystems & Environment 118: 267-272.
9. Buschmann, C., and E. Nagel. 1993. In vivo spectroscopy and internal optics of leaves as basis for remote sensing of vegetation. International Journal of Remote Sensing 14: 711-722.
10. Clevers, J. G. P. W., G. W. A. M. Van Der Heijden, S. Verzakov, and M. E. Schaepman. 2007. Estimating grassland biomass using SVM band shaving of hyperspectral data. Data Photogrammetric Engineering & Remote Sensing 73 (10): 1141-1148.
11. Cowley, R. B., D. J. Luckett, J. S. Moroni, and S. Diffey. 2014. Use of remote sensing to determine the relationship of early vigour to grain yield in canola (*Brassica napus* L.) germplasm. Crop & Pasture Science 65: 1288-1299.
12. Dominguez, J. A., J. Kumhalova, and P. Novak. 2017. Assessment of the relationship between spectral indices from satellite remote sensing and winter oilseed rape yield. Agronomy Research 15 (1): 055-068.
13. Gallego, J., E. Carfagna, and B. Baruth. 2010. Accuracy, objectivity and efficiency of remote sensing for agricultural statistics. PP 193-211 in R. Benedetti., M. Bee., G. Espa and F. Piersimoni eds. Agricultural Survey Methods. John Wiley & Sons Inc., New York.

14. Gitelson, A. A., Y. J. Kaufman, R. Stark, and D. Rundquist. 2002. Novel algorithms for remote estimation of vegetative fraction. Remote Sensing of Environment 80: 76-87.
15. Goel, P. K., S. O. Prasher, J. A. Landry, R. M. Patel, A. A. Viau, and J. R. Miller. 2003. Estimation of crop biophysical parameters through airborne and field hyperspectral remote sensing. Transactions of the ASAE 46 (4): 1235-1246.
16. Haboudane, D., J. R. Miller, E. Pattey, P. J. Zarco Tejada, and I. B. Strachan. 2004. Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: Modeling and validation in the context of precision agriculture. Remote Sensing of Environment 90: 337-352.
17. Huete, A. R., C. Justice, and W. Van Leeuwen. 1996. MODIS vegetation index (mod13). Algorithm theoretical basis document. Version 2. NASA Goddard Space Flight Center. Washington D. C.
18. Jago, R. A., M. E. J. Cutler, and P. J. Curran. 1999. Estimating canopy chlorophyll concentration from field and airborne spectra. Remote Sensing of Environment 68 (3): 217-224.
19. Jiang, Z., A. R. Huete, K. Didan, and T. Miura. 2008. Development of a two-band enhanced vegetation index without a blue band. Remote Sensing of Environment 112: 3833-3845.
20. Jin, X., L. Kumar, Z. Li, X. Xu, G. Yang, and J. Wang. 2016. Estimation of winter wheat biomass and yield by combining the aquacrop model and field hyperspectral data. Remote Sensing 8. Available at: http://https://doi.org/10.3390/rs8120972. Accessed 4 March 2019.
21. Johnson, D. M. 2016. A comprehensive assessment of the correlations between field crop yields and commonly used MODIS products. International Journal of Applied Earth Observation and Geo information 52: 65-81.
22. Johnson, L., F. Roczen, D. Youkhana, R. Nemani, and D. Bosch. 2003. Mapping vineyard leaf area with multispectral satellite imagery. Computers and Electronics in Agriculture 38: 33-44.
23. Kaab, A., M. Sharifi, H. Mobli, A. Nabavi-Pelesaraei, and K. Chau. 2019. Combined life cycle assessment and artificial intelligence for prediction of output energy and environmental impacts of sugarcane production. Science of the Total Environment 664: 1005-1019.
24. Kazem, M., S. Mirzaei, and B. Maadi. 2016. Canola cultivation. Taak Press. Tehran. (In Farsi).
25. Khalili, S. M., A. Rezaee, and A. Haji Ahmad. 2016. Ripe detection and estimation of rapeseed crop yield based on remote sensing image processing. Thesis of Master of Science. University of Tehran. (In Farsi).
26. Languille, F., A. Gaudel1, B. Vidal, R. Binet, V. Poulain, and T. Trémas, 2017. Sentinel-2B Image Quality commissioning phase results and Sentinel2 constellation performances. Conference on Sensors, Systems, and Next-Generation Satellites XXI Location: Warsaw, POLAND Date: SEP 11-14, 2017.
27. Lee, K. S., W. B. Cohen, R. E. Kennedy, T. K. Maiersperger, and S. T. Gower. 2004. Hyperspectral versus multispectral data for estimating leaf area index in four different biomes. Remote Sensing of Environment 91: 508-520.
28. Li, A., S. Liang, A. Wang, and J. Qin. 2007. Estimating Crop Yield from Multi-temporal Satellite Data Using Multivariate Regression and Neural Network Techniques. Photogrammetric Engineering & Remote Sensing 73 (10): 1149-1157.
29. Li, F., M. L. Gnyp, L. Jia, Y. Miaoa, Z. Yua, W. Koppe, G. Bareth, X. Chen, and F. Zhang. 2008. Estimating N status of winter wheat using a handheld spectrometer in the North China Plain. Field Crops Research 106 (1): 77-85.
30. Loveimi, N., A. Akram, N. Bagheri, and A. Haji Ahmad. 2019. Prediction of canola yield in some of growth stages by using Landsat satellite, OLI sensor. Journal of Iran Biosystems Engineering 50 (1): 101-113. (In Farsi).
31. Mkhabela, M. S., P. Bullock, S. Raj, S. Wang, and Y. Yang. 2011. Crop yield forecasting on the Canadian Prairies using MODIS NDVI data. Agricultural and Forest Meteorology 151: 385-393.
32. Mcbratney, A., B. Whelan, T. Ancev, and J. Bouma. 2005. Future Directions of Precision Agriculture. Journal of Precision Agriculture 6 (1): 7-23.
33. Norgholipor, F., H. Rezaei, K. Mirzashahi, and H. Haghighatnia. 2014. Integrative management instruction of soil fertility and canola feeding. Soil and Water Research Institute. Tehran. (In Farsi).
34. Panda, S. S., D. P. Ames, and S. Panigrahi. 2010. Application of Vegetation Indices for Agricultural Crop Yield Prediction Using Neural Network Techniques. Remote Sensing 2: 673-696.
35. Piekarczyk, J. 2011. Winter oilseed-rape yield estimates from hyperspectral radiometer measurements. Journal of Quaestiones Geographicae 30 (1): 77-84.
36. Pratt, S. 2013. Satellite crop estimate too low: Analysts. The Western Producer. Available at: https://www.producer.com/2013/10/satellite-crop-estimate-too-low-analysts. Accessed 28 March 2018.
37. Raun, W. R., J. B. Solie, M. L. Stone, E. V. Lukina, W. E. Thomason, and J. S. Schepers. 2001. In-season prediction of potential grain yield in winter wheat using canopy reflectance. Agronomy Journal 93: 131-138.
38. Rezaei, A., and S. A. Mirmohammadi. 2011. Statistics and probability, application in agriculture. Jahad Daneshgahi Sanati Esfahan Press. Tehran. (In Farsi).

39. Rischbeck, R., S. Elsayed, B. Mistele, G. Barmeier, K. Heil, and U. Schmidhalter. 2016. Data fusion of spectral, thermal and canopy height parameters for improved yield prediction of drought stressed spring barley. European Journal of Agronomy 78: 44-59.
40. Roodi, D., S. Rahmanpoor, and F. Javidfar. 2004. Cultivation of canola. Seed Breeding Research Institute. Tehran. (In Farsi).
41. Rostami, M. A., and H. Afzali Gorouh. 2017. Remote sensing of residue management in farms using Landsat 8 sensor imagery. Journal of Agricultural Machinery 7 (2): 388-400. (In Farsi).
42. Rouse, J. W., R. H. Haas, J. A. Schell, and D. W. Deering. 1974. Monitoring vegetation systems in the Great Plains with ERTS. Third Earth Resources Technology Satellite (ERTS) Symposium, NASA SP-351 I: 309-317. Washington D. C. USA.
43. Sanaeinejad, H., M. Nassiri Mahallati, H. Zare, N. Salehnia, and M. Ghaemi. 2014. Wheat yield estimation using Landsat images and observation. Journal of Plant Production 20 (4): 45-63. (In Farsi).
44. Schwalbert, R. A., T. J. C. Amado, L. Nieto, S. Varela, G. M. Corassa, T. A. N. Horbe, C. W. Rice, N. R. Peralta, and I. A. Ciampitti. 2018. Forecasting maize yield at field scale based on high-resolution satellite imagery. Biosystems Engineering 171: 179-192.
45. Shanahan, J. F., J. S. Schepers, D. D. Francis, G. E. Varvel, W. W. Wilhelm, J. M. Tringe, M. R. Schlemmer, and D. J. Major. 2001. Use of remote-sensing imagery to estimate corn grain yield. Agronomy Journal 93: 583-589.
46. Sicre, C. M., J. Inglada, R. Fieuzal, F. Baup, S. Valero, J. Cros, M. Huc, and V. Demarez. 2016. Early Detection of Summer Crops Using High Spatial Resolution Optical Image Time Series. Remote Sensing 8 (7): 591. Available at: http://doi:10.3390/rs8070591. Accessed 3 March 2019.
47. Sulik, J. J., and D. S. Long. 2016. Spectral considerations for modeling yield of canola. Remote Sensing of Environment 184: 161-174.
48. Vigneau, N., M. Ecarnot, G. Rabatel, and P. Roumet. 2011. Potential of field hyperspectral imaging as a nondestructive method to assess leaf nitrogen content in wheat. Field Crops Research 122: 25-31.
49. Weber, V. S., J. L. Araus, J. E. Cairns, C. Sanchez, A. E. Melchinger, and E. Orsini. 2012. Prediction of grain yield using reflectance spectra of canopy and leaves in maize plants grown under different water regimes. Field Crops Research 128: 82-90.
50. Yamamoto, K., W. Guo, Y. Yoshioka, and S. Ninomiya. 2014. On plant detection of intact tomato fruits using image analysis and machine learning methods. Journal of Sensors (Basel) 14 (7): 12191-12206.
51. Zahirnia, A., H. R. Matinfar, and M. Zinvand. 2016. Prediction of canola yield base on Landsat-8 in west south of Khouzestan province. 4th International conference on applied research in agricultural sciences. Tehran. (In Farsi).
52. Zhang, X., and He, Y. 2013. Rapid estimation of seed yield using hyperspectral images of oilseed rape leaves. Journal of Industrial Crops and Products 42: 416-420.
53. Zou, X. B., J. Y. Shi, L. M. Hao, J. W. Zhao, H. P. Mao, Z. W. Chen, Y. X. Li, and M. Holmes. 2011. In vivo noninvasive detection of chlorophyll distribution in cucumber (*Cucumis sativus*) leaves by indices based on hyperspectral imaging. Journal of Analytica Chimica Acta 706: 105-112.

Journal of Agricultural Machinery
Vol. 11, No. 2, Fall- Winter 2021, p. 447-464

نشریه ماشین‌های کشاورزی
جلد ۱۱، شماره ۲، نیمسال دوم ۱۴۰۰، ص ۴۶۴-۴۴۷

Evaluation of Several Spectral Indices for Estimation of Canola Yield using Sentinel-2 Sensor Images

N. Loveimi[1], A. Akram[2*], N. Bagheri[3], A. Hajiahmad[4]

Received: 23-04-2019
Accepted: 14-07-2019

Introduction

Remote sensing and using satellite images have been widely considered due to the high speed of measurement and great area of coverage. Canola is a source of edible oil and its cultivation in Iran and the world is developing. Comparing with other crops, canola, because of its yellow flowers, has a different canopy color, and only a few researches have been carried out in order to assess the spectral indices for prediction of its yield. Therefore, the main objective of this research is to evaluate some spectral vegetation indices to estimate the yield of canola in different growth stages.

Materials and Methods

The study was performed in 2016-2017 in Karaj, Iran. Three canola farms were chosen for the evaluation of the relationship between yield and some vegetation indices derived from the Sentinel-2 sensor. The sensor data were processed in five stages: before flowering, early flowering, peak of flowering, green and dry maturity, and the vegetation indices were extracted for each of them. This research was pixel-based and the pixels network of each studied farm was determined by RTKGPS. During harvesting time, for measurement of grain yield, five samples, four from the corners and one from the center of the pixel, were taken and their average was considered as the representative amount of the pixel. Totally, 112 pixels from three studied farms were used to calibrate the predictive models. By using Simple Linear Regression (SLR) models, ten new and conventional vegetation indices were assessed. Also, Multivariate Linear Regression (MLR) models and Artificial Neural Net (ANN) models with four bands, three visible bands and NIR band, as inputs, were used to predict the canola yield. In order to validate the SLR and MLR models, the "K-Fold" method of cross-validation was used, and for the validation of ANN models, 15% of data were used; 70% for the train, 15% for validation, and 15% for the test.

Results and Discussion

The results showed that, on the basis of SLR models, among the growth stages, the highest coefficient of determination (R^2) in each of the vegetation indices belonged to one of the two stages: the peak of flowering and green maturity. According to SLR models, among the vegetation indices in different stages, the NDYI in the peak of the flowering stage had the highest correlation with yield (R^2 = 73%). Also, the RVI with 29%, BNDVI with 52%, NDVI with 56%, and GNDVI with 35% had the highest R^2 in the before flowering, early flowering, peak of flowering, green and dry maturity stages, respectively. MLR models resulted to the best yield predictive model at the peak of flowering stage (R^2 = 76% for the calibration and R^2 = 73% and RMSE = 0.641 for the validation). For ANN models, the strongest model achieved at peak of flowering stage (R^2 = 92% for the calibration (train) and R^2 = 77% and RMSE = 0.612 for the validation (test)). It seems that the results are affected by yellow flowers of canola, and absorption of blue light by their petals. Therefore, in the peak of the flowering stage, the reflection of the blue light is more likely to belong to green leaves and stems. Therefore, any index such as NDYI, which the blue reflection is subtracted in its equation, represents better the number of flowers, and since the density of flowers is directly related to the yield, the yield will be predicted with more precision.

Conclusions

The results of the analysis of the indices by SLR models showed that the correlation of each of the vegetation indices with the canola yield, in different stages of growth, has a considerable difference. Based on this model,

1- PhD. Student, Department of Agricultural Machinery Engineering, Faculty of Agricultural Engineering and Technology, College of Agriculture & Natural Resources, University of Tehran, Karaj, Iran

2- Associate Professor, Department of Agricultural Machinery Engineering, Faculty of Agricultural Engineering and Technology, College of Agriculture & Natural Resources, University of Tehran, Karaj, Iran

3- Assistant Professor, Agricultural Engineering Research Institute, Agricultural Research, Education and Extension Organization (AREEO), Karaj, Iran

4- Assistant Professor, Department of Agricultural Machinery Engineering, Faculty of Agricultural Engineering and Technology, College of Agriculture & Natural Resources, University of Tehran, Karaj, Iran

(*- Corresponding Author Email: aakram@ut.ac.ir)

the highest R^2 in each of these indices happened in the peak of flowering or green maturity stage, and among these indices in different stages, the NDYI in the peak of the flowering stage had the highest R^2. Finally, in both of the MLR and ANN models, with four bands, three visible bands and near-infrared band, as inputs, the best yield predictive model resulted in the peak of the flowering stage.

Keywords: Normalized Difference Yellowness Index (NDYI), Remote sensing, Sentinel-2 sensor, Vegetation index, Yield prediction